

Une méthode Monte-Carlo pour les méandres sur ordinateur parallèle

O. Golinelli

*Cea Saclay, Service de physique théorique,
91191 Gif-sur-Yvette, France
email: golinelli@cea.fr*

sept. 1999

Preprint T99/109 ; cond-mat/9910004

Résumé

Pour modéliser le repliement compact d'un polymère, on étudie la statistique des méandres, définis comme configurations d'un circuit automobile traversant n fois une rivière. Grâce à une méthode Monte-Carlo adaptée à un ordinateur massivement parallèle, les méandres sont simulés jusqu'à la taille $n = 400$. Le comportement asymptotique du dénombrement et de l'enroulement moyen des méandres sont présentés.

Mots-clé : repliement, pliage, méandres, Monte-Carlo, arbre, parallélisme

1 Introduction

Un des centres d'étude actuel de la mécanique statistique est le repliement d'objets géométriques qui fluctuent, comme les membranes (à 2 dimensions) ou les polymères (à une dimension). Les exemples en physique et en biologie sont nombreux. Les concepts développés pour les phénomènes critiques (observés lors de certaines transitions de phase) s'appliquent aussi à ce domaine. En particulier, avec "l'universalité", certaines quantités décrivant le comportement critique à grande échelle sont indépendantes des détails à petite échelle (forme des monomères, interactions, ...). Le physicien théoricien cherche alors à représenter un objet complexe (par exemple, un polymère biologique) par le modèle, le plus simple possible pour pouvoir faire des calculs,

mais dont on pense qu'il présente les mêmes propriétés physiques à grande échelle.

Dans cet article, le repliement compact d'un polymère est modélisé par une bande de timbres-poste complètement repliée [1]. Ceci est équivalent au problème des *méandres*, résumé par cette simple question : de combien de manières M_n un circuit automobile peut-il traverser une rivière en n ponts, en contournant éventuellement la source ?

Une variante [2], où on interdit le contournement de la source, est équivalente à l'énumération des labyrinthes d'un certain type [3], ainsi qu'au 16ième problème de Hilbert, c'est à dire l'énumération des ovales de courbes planaires algébriques [4].

Ce problème a par ailleurs des connections avec la théorie des nœuds, les "modèles de matrice" et la "gravité quantique", et même la QCD (théorie des interactions nucléaires fortes en physique des particules).

Les méandres sont donc un modèle de repliement compact d'un objet à une dimension, avec des maillons identiques, dont on ne retient que l'ordre dans le pliage. Malgré cette simplification extrême, ce problème résiste depuis au moins un siècle : par exemple, on ne connaît toujours pas de formule pour le nombre de pliages possibles M_n , ni même son comportement asymptotique pour n grand.

L'approche présentée ici est purement numérique. Elle a été rendue possible en exploitant la puissance des ordinateurs parallèles. Cependant, la méthode de "brute force" ne permet pas d'aller bien loin et un algorithme Monte-Carlo efficace a été élaboré. La nature même des méandres rend difficile la vectorisation des boucles les plus internes du programme. Par contre, celui a été parallélisé avec des "gros grains", c'est à dire en divisant le travail en sous-tâches au plus haut niveau possible.

La Section 2 est consacrée aux définitions. La Section 3 présente un algorithme de dénombrement exact, lui-aussi parallélisé. La Section 4 décrit la méthode Monte-Carlo. Finalement, quelques résultats sont exposés Section 5.

2 Définitions

Un *méandre* de taille n est défini comme une configuration planaire d'une boucle qui ne se croise pas elle-même (la *route*), croisant une demi-droite (la *rivière* avec sa *source*) en n points (les *ponts*). Deux méandres de même taille sont considérés comme équivalents si l'un est obtenu à partir de l'autre en déformant continûment la route tout en gardant fixés les ponts. C'est une équivalence topologique.




FIG. 1: Les $M_4 = 4$ méandres de taille 4. La route est la boucle auto-évitante. La rivière semi-infinie est la demi-droite en trait plein, commençant à la source (point noir). La taille est le nombre de ponts. Le nombre d'enroulements w est le nombre d'arches croisant la demi-droite en pointillé à droite de la source. Les deux méandres du haut n'ont pas d'enroulement ($w = 0$), mais les deux du bas ont $w = 2$.

On appelle *arche* chaque section de route entre deux ponts. Un méandre de taille n a donc n ponts et n arches.

Le nombre de méandres différents de taille n est noté M_n . Par exemple, $M_1 = 1$, $M_2 = 1$, $M_3 = 2$ et $M_4 = 4$. Sur la Fig. 1, les 4 méandres de taille 4 sont dessinés.

Le problème des méandres est absolument équivalent à celui du repliement d'une bande de timbres-poste. Considérons une bande de n timbres attachée à un support. Il y a alors M_{n+1} manières de plier cette bande complètement, c'est à dire sous forme de pile avec un seul timbre en largeur. En effet, comme expliqué Fig. 2, chaque pliage de n timbres correspond à un méandre de taille $n + 1$ et réciproquement. On préfère cependant utiliser dans cet article la représentation sous forme de méandre car elle est plus naturelle pour décrire la récurrence avec laquelle nous les simulerons.

Les méandres ont des similitudes avec d'autres problèmes de physique statistique, par exemple les marches aléatoires auto-évitantes fermées : un méandre est obtenu à partir d'une telle marche en lui superposant une demi-droite et en ne gardant que l'aspect topologique, c'est à dire la nature des intersections. Aussi, par analogie, on attend que

$$M_n \stackrel{n \rightarrow \infty}{\sim} c \frac{R^n}{n^\gamma}, \quad (1)$$

où les estimations [5, 6] sont $R \sim 3.5$ et $\gamma \sim 2$.

Le nombre R , équivalent de la connectivité, peut être interprété comme le nombre moyen de possibilités pour ajouter un pont près de la source en ne déformant qu'une seule arche, pour un grand méandre. Ainsi, $\ln(R)$ apparaît




FIG. 2: On transforme un pliage de n timbres (ici $n = 4$) en un méandre de taille $n + 1$ de la manière suivante : (a) dessiner une boucle ovale traversant la pile de n timbres et se refermant sur la gauche en traversant le support. Il y a donc $n + 1$ intersections. (b) Mettre à plat la bande de timbres en tirant vers la droite son extrémité. On obtient alors un méandre avec $n + 1$ ponts, la boucle devenant la route, et la bande de timbres la rivière. La transformation inverse donne, à partir de tout méandre, une bande de timbre totalement repliée, en déformant la route pour en faire une boucle ovale.

comme l'entropie par pont ; c'est une quantité intensive, c'est à dire définie par unité de volume. Par contre, l'exposant γ sera sensible aux conditions au bord. Par exemple, si l'on change la définition du problème en prenant une rivière infinie aux deux bouts, ou bien une rivière avec un affluent, alors la connectivité R ne sera pas changée (elle caractérise l'effet du volume), mais par contre γ sera à chaque fois différent. Numériquement, γ est plus difficile à mesurer car il décrit la correction sous-dominante dans l'équation (1).

Pour un méandre donné, le nombre d'enroulements de la route autour de la source est défini comme le nombre minimal d'intersections entre la route et une demi-droite (semi-infinie) partant de la source en prolongeant la rivière du coté opposé. On peut le voir comme la distance topologique bout-à-bout entre la source (extrémité droite de la rivière) et l'infini (extrémité gauche), la distance entre deux points étant définie comme le nombre minimal d'arches à traverser pour aller d'un point à l'autre, sans franchir la rivière. Pour un exemple, voir Fig. 1.

On définit w_n comme la moyenne du nombre d'enroulements sur tous les M_n méandres de taille n . Par analogie avec les marches aléatoires, on s'attend à

$$w_n \stackrel{n \rightarrow \infty}{\sim} n^\nu, \quad (2)$$

avec $0 \leq \nu \leq 1$.

On peut étudier une variante des méandres où le nombre de routes est laissé libre ; les routes ne doivent pas se croiser, ni elles-mêmes, ni entre elles (mais peuvent être emboîtées) et le nombre total de ponts sur la rivière est

toujours fixé à n . Ce problème est alors exactement équivalent [7] à celui d'une marche aléatoire de $2n$ pas sur une demi-droite, le marcheur commençant et finissant à l'extrémité. Chaque marche correspond alors à une configuration de méandres et réciproquement. Il y a alors C_n marches possibles de ce type, où les C_n sont les nombres de Catalan $(2n)!/(n+1)!/n!$. On en déduit, pour ce modèle soluble, que $R = 4$, $\gamma = 3/2$ et $\nu = 1/2$ qui est l'exposant du mouvement Brownien. Mais en imposant qu'il n'y ait qu'une seule route, la nature du problème change complètement et les résultats exacts sont rares. En particulier, les valeurs ci-dessus changent et n'ont pas encore été calculées exactement.

On peut aussi définir d'autres quantités comme la forme moyenne des méandres ou leur aires. Plus de détails sont donnés dans la Ref. [8].

3 Dénombrement exact

Pour construire les méandres de taille $n+1$ à partir des méandres de taille n de façon systématique, plusieurs manières sont possibles. Malheureusement, aucune d'entre elles ne donne de récurrence directement entre le nombre total de méandres M_{n+1} , et M_n : il faut étudier séparément chacun des M_n méandres. Dans cette section, nous décrivons une méthode [6, 7], qui a été programmée sur un ordinateur parallèle, le Cray-T3D. Comme elle est à la base de l'algorithme Monte-Carlo, nous la présentons en détail.

Cette méthode consiste à ajouter un pont sur la partie la plus à gauche de la rivière et à modifier la route pour la faire passer par ce nouveau pont. Pour que ce changement soit minimal, seule une arche *extérieure* est modifiée (une arche est dite *extérieure* quand aucune autre ne l'entoure).

Prenons un méandre de taille n (le *père*) et choisissons (ou marquons) une de ses arches extérieures. Par le processus décrit Fig. 3, un méandre de taille $n+1$ (le *fil*) est construit. Le père a autant de fils que d'arches extérieures. En inversant le processus, chaque méandre de taille $n+1$ a un et un seul père. C'est donc une correspondance un-à-un entre, d'une part les méandres de taille $n+1$, et d'autre part, ceux de taille n avec une arche extérieure marquée.

Le point de départ de la récurrence est l'unique méandre de taille 1. En appliquant $n-1$ fois le processus, tous les méandres de taille n peuvent être construits. Comme décrit Fig. 4, l'ensemble des méandres s'organise comme un *arbre*. La racine, au niveau 1, est le méandre de départ $n=1$. Chaque branche entre un nœud au niveau n et un autre nœud au niveau $n+1$ représente une relation entre un père de taille n et un de ses fils de taille $n+1$. À l'exception de la racine $n=1$, chaque méandre (ou nœud) a




FIG. 3: Un méandre (fils) de taille $n + 1$ est construit à partir d'un père de taille n avec une arche extérieure marquée de la manière suivante : (a) Ajouter un pont sur la partie gauche de la rivière. Couper l'arche extérieure marquée et tirer sur ses deux extrémités libres. (b) Refermer cette arche du côté opposé en passant par le nouveau pont (et éventuellement en contournant la source par la droite). Le processus est inversible : (b) Ouvrir la route à l'emplacement du pont le plus à gauche (a) Prendre les deux extrémités libres et les refermer du côté opposé pour former une arche extérieure.

plusieurs arches extérieures, donc plusieurs fils (ou branches). Leur nombre dépend de la forme précise du méandre père et varie entre 2 et $n/2 + 1$. Il s'agit donc d'un arbre *déterministe* mais dont le nombre de branches dépend du nœud considéré.

Si l'on veut énumérer exactement les M_n méandres de taille n , la seule méthode que nous connaissons est de construire cet arbre jusqu'au niveau n . En particulier, nous n'avons pas trouvé de relation de récurrence directement entre les M_n . Le nombre de fils pour chaque méandre a une distribution qui semble erratique et le seul moyen de la connaître est l'examen de ses arches. Aussi, pour calculer M_n , le travail à fournir est proportionnel aux M_n , qui croissent exponentiellement : les limites de l'ordinateur sont vite atteintes.

Pour cela, on coupe donc l'arbre au niveau n . On appelle alors *feuilles* les nœuds de niveau n (qui représentent des méandres de taille n). L'algorithme, schématisé Fig. 5, consiste à visiter toutes les feuilles de la gauche vers la droite, à la manière d'un "écureuil méticuleux". Les règles sont les suivantes.




FIG. 4: L'arbre des méandres jusqu'à $n = 5$. Pour $n \geq 4$, seule une moitié est dessinée, l'autre étant obtenue par la symétrie haut-bas. Ainsi, $M_1 = 1$, $M_2 = 1$, $M_3 = 2$, $M_4 = 4$ et $M_5 = 10$. Chaque flèche représente un processus "père-fils".

(a) L'écureuil démarre à la racine. (b) Lorsque l'écureuil se trouve sur un nœud intermédiaire (qui n'est pas une feuille), il grimpe dans la branche la plus à gauche qu'il n'a pas encore visitée. S'il a déjà visité toutes les branches, il descend d'un niveau. (c) Lorsque l'écureuil se trouve sur une feuille, il descend d'un niveau.

Le lecteur peut se convaincre que ces règles décrivent bien une visite complète de l'arbre. Bien sur, lorsque l'écureuil se trouve sur un nœud, il mesure des quantités intéressantes, par exemple le nombre d'enroulements. Ces mesures sont cumulées et traitées à la fin de l'énumération.

D'un point de vue Fortran, plusieurs représentations des méandres sont possibles. Dans celle que nous avons finalement utilisée, chaque arche est codée par les numéros des deux ponts qu'elle relie. Il faut cependant distinguer les deux rives. Aussi, les ponts, vus de la rive supérieure, sont numérotés négativement de $-n + 1$ à 0 , de la gauche vers la droite. Vus de la rive inférieure, ils sont numérotés positivement de 1 à n , de la droite vers la gauche. Le pont le plus proche de la source porte les numéros 0 et 1 ; le plus éloigné les numéros $-n + 1$ et n . Ainsi, le système des n arches est codé par le tableau d'entiers $A(-n + 1 : n)$ où $A(i)$ est le numéro du pont relié par une arche au pont i . Voir Fig. 6 pour un exemple.

Ce codage est loin d'être optimal pour l'utilisation de la mémoire. On pourrait par exemple se contenter d'un tableau de $2n$ bits, où le bit i vaut 1




FIG. 5: *Algorithme de l'écureuil méticuleux : il visite toutes les feuilles de la gauche vers la droite.*




FIG. 6: *Pour ce méandre de taille 4, l'arche $(-1, 4)$ est représentée par $A(-1) = 4$ et $A(4) = -1$. Au total, $A(-3 : 4) = (-2, -3, 4, 3, 2, 1, 0, -1)$.*

(resp. 0) si le pont i est relié à un pont de numéro supérieur (resp. inférieur). Cependant ce codage permet de casser et de fusionner des arches efficacement. En effet, lorsque l'écureuil monte, une arche $(j, A(j))$ est cassée et donne deux arches limitées par le nouveau pont : $(-n, j)$ et $(A(j), n + 1)$. Lorsque l'écureuil redescend, les deux arches $(-n + 1, A(-n + 1))$ et $(A(n), n)$ fusionnent pour donner l'arche $(A(-n + 1), A(n))$, l'arche suivante à casser étant éventuellement celle commençant à $j = A(n) + 1$.

Le programme Fortran, Table 1, compte donc les méandres jusqu'à $n = nmax$ donné. Il est possible d'utiliser la symétrie haut-bas pour diviser le travail par deux. On peut aussi se contenter de ne construire les méandres que jusqu'à la taille $n - 1$ et le décompte de leurs arches externes donne M_n . On peut gagner k étages supplémentaires, en utilisant des formules, exponentiellement compliquées avec k , faisant intervenir pour chaque méandre de

```

Integer, Parameter :: nmax = 20 ! hauteur maximale
Integer :: A(-nmax+1:nmax) = 0 ! representation en arches
Integer :: n = 1 ! hauteur de l'ecureuil
Integer :: j ! branche a visiter
Integer :: M(nmax) = 0 ! compte les meandres de
! taille n
A(0) = 1 ! meandre de depart

Arbre : Do ! parcours de l'arbre
M(n) = M(n) + 1 ! visite d'un nouveau noeud
j = -n + 1 ! arche la plus a gauche

Do While (n==nmax .or. j==n+1) ! Descente :
A(A(-n+1)) = A(n) ! on fusionne les deux
A(A(n)) = A(-n+1) ! arches externes
j = A(n) + 1 ! arche suivante a casser
n = n - 1
If (n == 0) Exit Arbre ! fin du parcours
Enddo

A(A(j)) = n+1 ! Montee :
A(n+1) = A(j) ! l'arche (j) est cassee
A(j) = -n
A(-n) = j
n = n + 1
Enddo Arbre

Print '(i3,i15)', (n, M(n), n = 1, nmax)
End

```

TAB. 1: *Programme Fortran qui compte les méandres jusqu'à $n = nmax$.*




FIG. 7: *Parallélisation de l'algorithme de l'écureuil méticuleux : dans une phase initiale très courte, tous les processeurs construisent l'arbre jusqu'à une hauteur n_1 . Les méandres obtenus sont alors pris comme nouveaux points de départ et le travail est réparti de manière cyclique entre tous les processeurs, notés ici P0, P1 et P2.*

taille $n - k$, les nombres de ses arches externes, de ses arches de profondeur 2, ..., jusqu'à la profondeur k . Le choix optimal est $k = 4$ ou 5.

Ce programme est clairement anti-vectorel. Pour donner un ordre de grandeur, avec $n = 20$, $M_{20} = 102511418$ est obtenu en 31 secondes sur un Sun avec UltraSparc à 360 MHz. Il met 70 secondes sur une machine vectorielle : le Fujitsu VPP-300 du Cea-Grenoble. Pour étudier les n les plus grands possible avec cet algorithme (qui est le seul dont on dispose), il ne reste plus que la voie du *parallélisme massif*, où l'ordinateur dispose de nombreux processeurs calculant indépendamment et interconnectés par un réseau rapide.

Pour cela, une taille intermédiaire n_1 est choisie. Dans une première phase, très courte, l'arbre est construit, sur chaque processeur, jusqu'au niveau n_1 . On obtient donc M_{n_1} "petits" méandres, par exemple $M_{11} = 4210$ avec $n_1 = 11$.

Dans une seconde phase, longue et massivement parallèle (voir Fig. 7), chacun de ces petits méandres est considéré comme la *racine* d'un arbre, qui est alors un sous-arbre de l'arbre global. Chaque sous-arbre est traité indépendamment des autres. Sur une machine parallèle, le travail est réparti entre tous les processeurs, chacun traitant, à peu près, le même nombre de sous-arbres. A la fin, les mesures sont collectées, sommées et traitées par un seul processeur.

Pour un sous-arbre donné, le travail à faire est proportionnel à son nombre de nœuds : il fluctue sensiblement d'un sous-arbre à l'autre. Mais comme chaque processeur a plusieurs dizaines de sous-arbres à traiter, on constate

n	M_n	n	M_n
1	1	16	1053874
2	1	17	3328188
3	2	18	10274466
4	4	19	32786630
5	10	20	102511418
6	24	21	329903058
7	66	22	1042277722
8	174	23	3377919260
9	504	24	10765024432
10	1406	25	35095839848
11	4210	26	112670468128
12	12198	27	369192702554
13	37378	28	1192724674590
14	111278	29	3925446804750
15	346846		

TAB. 2: Les nombres M_n de méandres de taille n pour $n \leq 29$, obtenus par énumération exacte sur ordinateur parallèle.

que les fluctuations se moyennent et l'équilibrage des charges entre processeurs est réalisé à quelques % près. Il n'est donc pas nécessaire d'utiliser de méthode plus sophistiquée.

Pour programmer cela sur un Cray-T3D, les directives de compilation *Craft*, fournies par le constructeur, ont été utilisées, car l'algorithme s'y prêtait bien. Cette extension de Fortran est du type "data-parallel" et a été remplacée depuis par Hpf. Une directive *barrier* synchronise tous les processeurs avant la collecte des résultats, qui se fait par le biais d'un tableau *partagé*, où chaque processeur y écrit le résultat de son dénombrement. Puis, grâce à des directives *master* et *end master*, seul un processeur fait et traite les sommes. La difficulté principale n'a donc pas été le codage en soi de l'algorithme dans le langage parallèle, mais bien la mise au point d'une parallélisation efficace.

Les résultats jusqu'à $n = 29$, donnés Table 2, ont été obtenus en 163 heures réparties sur 128 processeurs du Cray-T3D du Cea-Grenoble en 1995. On voit que les M_n croissent exponentiellement. Après extrapolation pour $n = \infty$, on en déduit que $R = 3.50(1)$ et $\gamma \approx 2$.

Si la puissance des ordinateurs continue de croître exponentiellement au fil des années, comme le temps de calcul est proportionnel aux M_n qui croissent eux-aussi exponentiellement, le mieux qu'on puisse espérer avec cette méthode de dénombrement exact est un gain d'une nouvelle taille (de n à

$n + 1$) tous les deux ans environ.

4 Méthode Monte-Carlo

Nous avons vu dans la section précédente que la méthode d'énumération exacte était vite limitée car le nombre M_n de méandres à construire croît exponentiellement avec la taille n . L'idée générale des méthodes Monte-Carlo est de remplacer l'analyse complète de tous les cas possibles par la sélection *aléatoire* d'un sous-ensemble. Celui sera représentatif si la moyenne obtenue avec ces échantillons est proche du vrai résultat (qui est inconnu). Cette moyenne est aléatoire et fluctue d'une expérience numérique à l'autre, ces fluctuations étant alors empiriquement mesurables.

Pour le problème des méandres, comme on ne sait construire efficacement un méandre de taille $n + 1$ qu'à partir d'un méandre de taille n , nous allons nous servir de l'arbre décrit plus haut.

Nous allons d'abord introduire la méthode qui utilise *un* écureuil Monte-Carlo. Malheureusement cette méthode n'est pas efficace car ses fluctuations statistiques croissent très vite avec n . La parade consiste alors à utiliser une grande population d'écureuils, méthode qui, de plus, est parallélisable.

4.1 Un écureuil Monte-Carlo

La vie de l'écureuil Monte-Carlo commence à la racine de l'arbre (à $n = 1$). Il grimpe de manière aléatoire dans l'arbre. A chaque niveau n , il se trouve sur un nœud de l'arbre (qui représente un méandre de taille n) et fait un certain nombre de mesures. Il grimpe au niveau $n + 1$ en choisissant au hasard de manière uniforme l'une des b_n branches partant de ce nœud. L'écureuil s'arrête à une certaine hauteur n_{max} fixée à l'avance.

Comme représentée Fig. 8, la probabilité que l'écureuil atteigne au niveau n un nœud donné n'est pas uniforme. Elle vaut $1/q_n$ où

$$q_n = b_1 \cdot b_2 \cdot \dots \cdot b_{n-1} \quad (3)$$

est le produit des nombres de branches b_i que l'écureuil a rencontrés à chaque nœud lors de son ascension, et qu'il peut donc calculer.

Ce processus, c'est à dire une ascension Monte-Carlo d'un seul écureuil, est considéré comme *une* simulation. De nombreuses simulations indépendantes sont réalisées et les mesures sont moyennées. Pour cela, il faut les pondérer avec le poids q_n . Ainsi, chaque méandre contribue au résultat avec probabilité $1/q_n$ et, le cas échéant, le poids q_n , donc de manière uniforme.




FIG. 8: La probabilité (nombres du haut) d'atteindre une feuille donnée est le produit des probabilités d'embranchement (nombres intermédiaires) rencontrées à chaque noeud. Elle n'est pas uniforme.

En particulier, l'espérance mathématique $\langle q_n \rangle$, définie comme la moyenne sur toutes les simulations possibles, vaut M_n .

Malheureusement, cette méthode ne marche pas en pratique pour n grand. En effet, bien que la loi de probabilité de chaque b_i soit régulière, la loi des q_n , produit d'un grand nombre de b_i , n'est pas *auto-moyennante* : dans la limite n grand, avec probabilité 1, les q_n obtenus par simulation sont bien plus petits que l'espérance mathématique $\langle q_n \rangle$. En effet, le théorème de la limite centrale s'applique à $\ln q_n$, qui est auto-moyennant car somme des $\ln b_i$, mais pas à q_n . Plus précisément, des événements exponentiellement rares avec n contribuent de manière exponentiellement grande à $\langle q_n \rangle$. Dans une simulation, la moyenne des q_n observés sera dominée par ces événements rares et les fluctuations seront larges. Il faut donc un nombre exponentiellement grand (avec n) de simulations. Dans la pratique, on ne peut pas dépasser $n \approx 30$ ou 35.

4.2 Méthode Monte-Carlo multi-écureuil

La méthode précédente est généralisée en utilisant une population de S écureuils, où S est un paramètre fixé à l'avance. Il est plus simple de le choisir parmi la liste des M_n : $S = M_{n_0}$. Ainsi, au départ, chaque nœud au niveau n_0 est occupé par un écureuil. Dans ce travail, $n_0 = 17$ et la symétrie haut-bas a été utilisée pour réduire la population à $S = M_{17}/2 = 1\,664\,094$ écureuils.

Les S écureuils évoluent, de manière synchrone, du niveau n au niveau $n+1$ par le processus suivant, schématisé Fig. 9. Considérons l'écureuil d'index i sur un nœud au niveau n , connecté à b_i nœuds du niveau $n+1$. Il se reproduit et donne b_i fils, chacun d'entre eux vivant sur un de ces b_i nœuds supérieurs. Tous les écureuils se reproduisent en même temps et le nombre total de fils




FIG. 9: La méthode Monte-Carlo multi-écureuil est ici schématisée avec $S = 2$ écureuils ($E1$ et $E2$). Leurs $S' = 5$ fils ($F1$ à $F5$) sont énumérés. Pour garder S constant, ils sont décimés et seulement $S = 2$ fils, choisis au hasard, survivent. Ce processus est itéré jusqu'à atteindre la hauteur voulue l'arbre.

$S' = \sum_{i=1}^S b_i$ est calculé. Le taux de reproduction moyen $B_n = S'/S$ est une estimation du rapport M_{n+1}/M_n . Pour empêcher la croissance exponentielle de la population (et donc des besoins en mémoire et en Cpu), celle-ci est gardée constante : seulement S parmi les S' fils survivent. Le choix est fait au hasard de manière uniforme. La probabilité de survie d'un fils est donc $1/B_n$. Cette décimation est l'étape Monte-Carlo de l'algorithme. Puis, le processus s'applique à nouveau aux fils ; il est itéré jusqu'à atteindre une hauteur n_{max} fixée à l'avance. Cela constitue *une* simulation. De nombreuses simulations indépendantes sont réalisées : les moyennes et leurs barres d'erreur associées sont alors calculées.

On voit que le cas particulier $S = 1$ n'est rien d'autre que la méthode précédente à *un* écureuil. A l'opposé, la limite $S = \infty$ est équivalente à la méthode d'énumération exacte car on ne supprime pas d'écureuil.

Mais quelque soit S , comme pour $S = 1$, la probabilité qu'un nœud soit visité par un écureuil n'est pas uniforme et il y a toujours un biais. Par exemple, les nœuds qui ont peu de frères, de cousins, ..., ont plus de chance d'être visités. On peut montrer [8] que ce biais est exactement corrigé si les mesures sont pondérées, pour chaque simulation, par

$$q_n = B_{n_0} \dots B_{n-2} \cdot B_{n-1}, \quad (4)$$

produit des facteurs de décimation.

A priori, cette méthode souffre des mêmes défauts que la précédente, car le poids q_n est le produit de nombreux B_i aléatoires, donc non auto-moyennant quand n devient grand. Mais, l'amélioration capitale est que la distribution de B_i devient très piquée autour de M_{i+1}/M_i quand la population S est

grande. En effet, B_i étant le nombre de fils en moyenne pour S écureuils, ses fluctuations sont faibles et d'ordre $O(1/\sqrt{S})$. Pour le dire autrement, dans l'expression de q_n , la moyenne sur les S écureuils est faite au niveau des B_i , donc *avant* leur produit. Les fluctuations de q_n croissent certes toujours exponentiellement, mais avec un taux très faible si S est grand. Par exemple, pour $S = 1\,664\,094$ et $n = 400$, la largeur σ de la distribution des q_n est de 12% avec quelques événements rares allant jusqu'à trois fois la moyenne.

Comment choisir S et n ? Naïvement, on a envie de simuler les méandres de taille n la plus grande possible. Mais, pour réaliser N_s simulations indépendantes avec S écureuils jusqu'à la taille n , le besoin de mémoire d'ordinateur est d'ordre $O(n.S)$ et celui de temps Cpu d'ordre $O(n^2.S.N_s)$. Avec S suffisamment grand, les fluctuations statistiques sont presque gaussiennes et d'ordre $O(1/\sqrt{S.N_s})$. Comme n est toujours limité, nous extrapolerons pour étudier la limite n infini. L'allocation de temps d'ordinateur étant fixée par ailleurs, nous nous sommes limités à $n \leq 400$, pour bien extrapoler avec une meilleure statistique. Finalement, à produit $S.N_s$ constant, il vaut mieux choisir S le plus grand possible permis par la mémoire de l'ordinateur, pour diminuer le problème des fluctuations rares et grandes de q_n .

L'algorithme a été ici décrit en terme d'écureuils. Mais ceux-ci représentent des méandres par l'intermédiaire d'un tableau d'entiers $A(-n+1 : n)$. En particulier, l'opération qui transforme un écureuil en son fils, consiste à casser une arche externe, donc à manipuler ce tableau. Cette opération n'est pas vectorisable et s'avère être la partie qui consomme le plus de Cpu dans l'algorithme. Comme dans toute simulation Monte-Carlo, la qualité statistique des résultats est limitée par le temps Cpu. Il est alors capital de paralléliser l'algorithme.

La parallélisation la plus simple consiste à réaliser des simulations totalement indépendantes sur chacun des processeurs. Il suffit d'initialiser différemment le générateur de nombres aléatoires d'un processeur à l'autre, et d'organiser la collecte des mesures effectuées lors des simulations pour les traiter ultérieurement. Ce type de parallélisation n'utilise que très peu le réseau car rien n'est échangé entre les processeurs. Cela peut même se concevoir sur un réseau hétérogène de stations de travail, de manière asynchrone.

Mais on a vu ci-dessus qu'il était très important de simuler la plus grande population possible, plutôt que de multiplier les simulations avec une population plus petite, la limite étant donnée par la mémoire disponible. Pour cela, tous les processeurs doivent travailler de concert sur la même population. L'algorithme utilisé est décrit ci-après.

Dans une courte phase d'initialisation, les S écureuils sont construits au niveau n_0 et sont répartis de manière équilibrée parmi les processeurs. Chaque processeur ne s'occupe que de son groupe d'écureuils.

Lors d'une itération principale, où la population passe du niveau n au niveau $n + 1$, chaque processeur énumère les fils de ses écureuils, puis réalise et somme ses mesures. Les sommes globales sont ensuite faites sur l'ensemble des processeurs et écrites dans un fichier par un seul processeur pour être analysées ultérieurement. Le facteur de décimation B_n doit être déterminé de manière globale, et non pas localement sur chaque processeur. Un processeur, déclaré maître, analyse le nombre de fils F_p obtenus par chaque processeur p , calcule B_n et fixe en retour le nombre F_p/B_n de fils que chaque processeur doit garder. La population globale est donc maintenue exactement égale à S . Cette phase demande une synchronisation entre processeurs, peu de calculs et l'échange de petits messages. Puis vient la décimation proprement dite, réalisée de manière indépendante sur chacun des processeurs. C'est l'étape qui consomme le plus de Cpu car les fils survivants sont effectivement construits à ce moment-là.

Il est alors nécessaire d'équilibrer les populations entre processeurs. En effet, le nombre de fils fluctue. Lors de la synchronisation, tous les processeurs doivent attendre celui qui a le plus d'écureuils, car il effectue plus de travail. Sans y remédier, ce problème empirerait au fil des itérations. Aussi, à la fin de chaque itération, le processeur maître recense les processeurs dont la population dépasse de 5 % la moyenne et leur fait transférer la partie excédentaire aux processeurs les moins chargés. Ainsi, les temps d'attente sur la barrière de synchronisation sont en moyenne de 5 %. En contrepartie, le réseau transfère 5 % de la mémoire de quelques processeurs.

Ce processus constitue *une* simulation. Plusieurs simulations sont effectuées de manières indépendantes, en un ou plusieurs "runs". Les fichiers de mesures sont ensuite traités par un autre programme.

Cette parallélisation a été programmée sur le Cray-T3E du Cea-Grenoble, équipé de processeurs Dec-alpha à 375 MHz. Il faut 13 Goctets de mémoire pour une population de $S = 1\,664\,094$ écureuils, soit 128 processeurs de 128 Moctets. Pour réaliser 8192 simulations, 8 jours ont été nécessaires, soit 24000 heures de Cpu. Pour paralléliser, la bibliothèque Shmem, fournie par le constructeur, a été utilisée. Elle est du type "passage de message", comme PVM ou MPI. Son intérêt principal est sa simplicité et son efficacité. Par contre, elle n'est pas portable.

Le rendement de la parallélisation est proche des 95 % théoriques. Aucune dégradation significative n'a été vue, même avec 128 processeurs. En effet, les échanges entre processeurs sont rares et de volume moyen : ils ne posent aucun problème pour le réseau du T3E, qui est un point fort de cette machine. La performance du programme est plutôt sensible aux problèmes d'accès au cache et à la mémoire locale ; un gain important a été obtenu, lors des copies de tableaux dans une même mémoire locale, grâce aux registres "E", en

court-circuitant le Cpu et son cache.

On voit que le travail scalaire par processeur est proportionnel à son nombre d'écureuils ; par contre la taille des messages est proportionnelle aux fluctuations, donc à la racine carrée. En théorie, la “scalabilité” est parfaite, à condition d'augmenter la population globale — ce qui est justement intéressant — quand on augmente le nombre de processeurs, pour que la population par processeur ne s'appauvrisse pas.

5 Quelques résultats

On s'intéresse tout d'abord au comportement asymptotique du nombre de méandres $M_n \sim cR^n/n^\gamma$ pour n grand. L'entropie $\ln R$ peut être estimée avec

$$L_n = \frac{1}{2} \ln \left(\frac{M_n}{M_{n-2}} \right), \quad (5)$$

où n saute de 2 en 2 pour diminuer des effets sensibles de parité entre les n pairs et impairs. Comme on s'attend à $L_n \sim \ln R - \gamma/n$ pour n grand, en traçant $y = L_n$ en fonction de $x = 1/n$, on pourra estimer $\ln R$ (limite quand x tend vers 0) et γ (pente asymptotique).

Sur la Fig. 10, l'estimation Monte-Carlo de $L_n - \ln 3.5 + 2/n$ est tracée en fonction de $1/n$ pour n allant de 50 à 400. La fonction *linéaire* $y = \ln 3.5 - 2x$ a été arbitrairement soustraite pour réduire l'amplitude de variation de y ; les quantités intéressantes $2 - \gamma$ (pente résiduelle), $\ln(R/3.5)$ (limite quand x tend vers 0) et la courbure (déviations au comportement linéaire espéré) sont ainsi rendues plus visibles. Malgré cette amplification, la courbure reste faible et rend raisonnable une extrapolation linéaire, qui donne

$$R = 3.5019(2) \quad \text{et} \quad \gamma = 2.056(10), \quad (6)$$

en contradiction avec les conjectures $7/2$ et 2 .

L'*exposant d'enroulement* ν , défini par le comportement asymptotique du nombre moyen d'enroulements $w_n \sim n^\nu$, est présenté Fig. 11. En traçant $\ln(w_n)$ en fonction de $\ln n$, la pente asymptotique est une mesure de ν . Nous préférons utiliser $\ln(w_n + 1)$ au lieu de $\ln(w_n)$, car on remarque que $w_n + 1$ est moins sensible que w_n aux effets de taille finie. Comme la question principale est de savoir si $\nu = 1/2$ ou non, la fonction *linéaire* $y = x/2$ a été soustraite. Ainsi, la variation de y est réduite ; $\nu - 1/2$ et la courbure sont plus visibles. On voit que cette dernière reste petite et une extrapolation linéaire donne

$$\nu = 0.518(2), \quad (7)$$




FIG. 10: *Estimation Monte-Carlo de $L_n - \ln 3.5 + 2/n$ en fonction de $1/n$ pour n allant de 50 à 400. La limite quand x tend vers 0 est $\ln(R/3.5)$, et la pente (négative) est $2 - \gamma$. Les barres d'erreur ne sont pas dessinées car elles sont toujours inférieures à 10^{-5} , donc plus petites que les symboles. Un effet de parité entre les n pairs et impairs est visible. Une extrapolation linéaire donne $R = 3.5019(2)$ et $\gamma = 2.056(10)$.*




FIG. 11: *Estimation Monte-Carlo de $\ln(w_n + 1) - 1/2 \ln n$ en fonction de $\ln n$, pour n entre 8 et 400. La pente est de 0.018 et mesure $\nu - 1/2$. Les barres d'erreur ne sont pas dessinées car inférieures à $3 \cdot 10^{-4}$.*

incompatible avec la valeur brownienne $1/2$.

D'autres résultats sont présentés dans la Réf [8], concernant la loi de probabilité du nombre d'enroulements et la forme moyenne des méandres, en particulier près de la source et de l'extrémité opposée.

6 Conclusion

Dans ce travail, nous avons simulé le repliement compact d'un objet unidimensionnel, une bande de n timbres-poste, modélisée par les méandres. Jusqu'à présent, on ne connaît pas de formule donnant le nombre de pliages possibles M_n en fonction de n , et l'ordinateur est donc une méthode d'investigation privilégiée. Les algorithmes, que nous avons développés et utilisés, reposent sur une représentation de l'ensemble de tous les pliages possibles en un arbre de forme irrégulière.

Avec un algorithme de visite systématique de tous les nœuds de l'arbre jusqu'à une hauteur fixée n , on peut mesurer exactement toutes les propriétés. Mais la nature même de l'arbre empêche la vectorisation, car il n'y a pas de longue boucle régulière. Par contre, la possibilité de le découper en sous-arbres rend la parallélisation efficace sur une machine à grand nombre de processeurs. Mais le travail croît exponentiellement avec n et même un ordinateur puissant ne permet pas de dépasser $n \sim 30$.

Avec un algorithme Monte-Carlo, on peut étudier des méandres plus grands. Mais les fluctuations statistiques, inhérentes à ce type de méthode, sont ici particulièrement défavorables. Avec la mise au point de la méthode multi-écureuil, les moyennes sont réalisées en deux étapes : la première, entre écureuils, a des fluctuations gaussiennes, le cas le plus favorable. On cherche donc à simuler simultanément le plus grand nombre possible d'écureuils, ce qui est principalement limité par la mémoire de l'ordinateur. En répartissant la population sur de nombreux processeurs, la parallélisation permet alors de bénéficier de beaucoup plus de mémoire. On obtient aussi une forte puissance en Cpu scalaire, nécessaire pour que les résultats significatifs ne soient pas noyés dans les fluctuations statistiques, ce qui a permis alors des simulations jusqu'à la taille $n = 400$.

On voit donc que les études décrites dans cet article doivent beaucoup aux ordinateurs parallèles, les ordinateurs vectoriels étant inefficaces pour ces algorithmes. La parallélisation étant hors de portée d'un compilateur automatique, elle doit être explicitement programmée, le "passage de message" s'avérant le mieux adapté.

Remerciements

Nous remercions L. Colombet, P. Di Francesco, E. Gitter et R. Napoleone pour toutes les discussions enrichissantes et l'aide à la parallélisation des programmes.

Références

- [1] A. Sainte-Laguë, *Avec des nombres et des lignes*, (Vuibert, Paris 1937, réédité en 1994).
- [2] S. K. Lando, A. K. Zvonkin, *Meanders*, Selecta Math. Sov. 11 (1992) 117 ; *Plane and projective meanders*, Theoretical Computer Science 177 (1993) 227.
- [3] A. V. Phillips, www.math.sunysb.edu/~tony/mazes.
- [4] V. I. Arnold, *A branched covering of CP^2 to S^4 , hyperbolicity and projectivity topology*, Siberian Math. J. 717-725 (translated from Sibirskii Matematicheskii Zhurnal 29 (1998) 36).
- [5] W. F. Lunnon, *A map-folding problem*, Math. of Computation 22 (1968) 193.
- [6] P. Di Francesco, O. Golinelli, E. Gitter, *Meander, folding, and arch statistics*, Math. Comput. Modelling 26 (1997) 97 or hep-th/9506030.
- [7] P. Di Francesco, O. Golinelli, E. Gitter, *Meanders : a direct enumeration approach*, Nucl. Phys. B 482 (1996) 497.
- [8] O. Golinelli, *A Monte-Carlo study of meanders*, preprint cond-mat/9906329, à paraître dans Eur. Phys. J. B (2000).